

УДК 004.85

DOI: 10.18413/2518-1092-2025-10-1-0-8

Ясир М.Дж.¹
Аль Жанзир З.М.²**РАСПОЗНАВАНИЕ И КЛАССИФИКАЦИЯ
МРТ-ИЗОБРАЖЕНИЙ ГОЛОВНОГО МОЗГА
С ИСПОЛЬЗОВАНИЕМ НЕЙРОННЫХ СЕТЕЙ**¹⁾ Южный технический университет, ул. Шоссе Зубаир, г. Басра, 61001, Ирак²⁾ Белгородский государственный университет,
ул. Победы, 85, Белгород, 308015, Россия*e-mail: muhaned.yaser@stu.edu.com, 689419@bsuedu.ru***Аннотация**

В статье представлено исследование, посвященное разработке нейросетевого инструментария для классификации изображений магнитно-резонансной томографии (МРТ). Исследование посвящено решению актуальной научно-технической задачи, нацеленной на повышение точности диагностирования онкологических заболеваний человеческого мозга. Предложена модель, основанная на использовании нейросети прямого распространения. Модель имеет три скрытых слоя нейронов, использующих функцию активации Relu. Выходной слой нейронов использует функцию активации Softmax. Сеть создавалась с помощью библиотеки Keras и программной библиотеки OpenCV. Проведена проверка работоспособности предложенной нейросети, которая показала высокую точность результатов классификации изображений. Применение данной модели позволяет на 9,6 % повысить точность диагностирования онкологических заболеваний головного мозга человека по сравнению с традиционными методами.

Ключевые слова: нейронная сеть прямого распространения; распознавание изображений; магнитно-резонансная томография; Keras; онкология головного мозга

Для цитирования: Ясир М.Дж., Аль Жанзир З.М. Распознавание и классификация МРТ-изображений головного мозга с использованием нейронных сетей // Научный результат. Информационные технологии. – Т. 10, №1, 2025. – С. 77-85. DOI: 10.18413/2518-1092-2025-10-1-0-8

Yaser M.J.¹
Al Janzeer Z.M.²**RECOGNITION AND CLASSIFICATION OF MRI IMAGES
OF THE BRAIN USING THE NEURAL NETWORKS**¹⁾ Southern Technical University, Zubair Highway St., Basra, 61001, Iraq²⁾ Belgorod State University,
85 Pobedy St., Belgorod, 308015, Russia*e-mail: muhaned.yaser@stu.edu.com, 689419@bsuedu.ru***Abstract**

The article presents a study devoted to the development of neural network tools for classifying magnetic resonance imaging (MRI) images. The study is devoted to solving a pressing scientific and technical problem aimed at improving the accuracy of diagnosing oncological diseases of the human brain. A model based on the use of a feedforward neural network is proposed. The model has three hidden layers of neurons using the Relu activation function. The output layer of neurons uses the Softmax activation function. The network was created using the Keras library and the OpenCV software library. The sizes of images used as training data are substantiated. The study showed that 38 training cycles are sufficient to configure such a neural network. The performance of the proposed neural network was tested, which showed high accuracy of image classification results. The use of this model allows to increase the accuracy of diagnosing oncological diseases of the human brain by 9.6% compared to traditional methods.

Keywords: Feed Forward Neural Network; image recognition; magnetic resonance imaging; Keras; brain oncology

For citation: Yaser M.J., Al Janzeer Z.M. Recognition and classification of MRI images of the brain using the neural networks // Research result. Information technologies. – Т. 10, №1, 2025. – P. 77-85. DOI: 10.18413/2518-1092-2025-10-1-0-8

ВВЕДЕНИЕ

Распознавание изображений связано с получением цифровой визуализации для идентификации различных объектов или функций. Задачи распознавания и классификации изображений актуальны во многих сферах человеческой деятельности, особенно в медицине [1-3]. Интеллектуальные средства анализа изображений созданы для диагностики самых различных заболеваний. Предложены модели, позволяющие с высокой точностью классифицировать диабетическую ретинопатию [4], острые лейкозы [5], клетки крови [6]. Разработан инструментарий обработки изображений для диагностики заболеваний гортани [7], хронического риносинусита [8], дерматологических болезней [9].

Перспективным подходом для решения задач автоматической обработки и анализа данных является применение методов искусственного интеллекта [10-16]. Современные интеллектуальные методы базируются, в основном, на использовании искусственных нейронных сетей. Они представляют собой адаптивные системы, функционирование которых имитирует работу человеческого мозга [17]. Нейросети способны изменять свою структуру и внутренние связи, приспосабливаясь к особенностям решаемых задач. Технологии распознавания изображений на основе применения искусственных нейронных сетей применяются для идентификации мнений Интернет-пользователей, номерных знаков, диагностики заболеваний [17]. Одной из важных функций распознавания изображений в области медицины является определение наличия злокачественных образований на изображениях органов человеческого тела [18].

В основе искусственных нейронных сетей лежат связанные между собой узлы, моделирующие работу нейронов. Из таких узлов могут формироваться многие слои искусственных нейронов. Каждый узел имеет вход, выход и функцию активации, которая преобразует глобальные входные данные в выходные данные, как показано на рисунке 1.

Распространенной нейросетевой моделью является сеть с прямой связью (Feed Forward Neural Network, FFNN) [20]. Такая модель не содержит замкнутых путей. Отсутствуют дуги, ведущие ко входным узлам этой нейросети, так же, как и её выходные узлы не имеют отходящих от них дуг. Остальные слои узлов именуется скрытыми. Состояния нейронов скрытых слоев подстраиваются в зависимости от заданных состояний входных узлов [21]. В процессе функционирования нейросети с прямой связью с учетом набора входных данных вычисляются значения выходных данных.

Выбор FFNN-сети для проведения наших исследований обусловлен, с одной стороны, относительной структурной простотой этого инструментария, с другой стороны, способностью при этом достичь сопоставимой производительности при достаточном объеме данных и использовании эвристического подхода. Это дает возможность упростить создание нейросетевых моделей и управление ими.




Рис. 1. Схема многослойной нейронной сети
Fig. 1. Multilayer neural network diagram

Чтобы снизить ошибки классификации снимков магнитно-резонансной томографии, используются следующие методы повышения качества изображений:

- выравнивание гистограммы (histogram equalization) [22];
- адаптивное выравнивание гистограммы (adaptive histogram equalization) [23];
- морфологический фильтр (morphology filter) [24].

Проведен анализ, который показал, что применение известных методов и моделей позволяет улучшить контрастность и яркость, но вносят значительный шум в изображения. Использование таких улучшенных изображений приводит к ошибкам нейросетевой классификации. Чтобы уменьшить эти ошибки, необходимо предложить модель FFNN-нейросети, позволяющую повысить точность классификации МРТ-изображений.

ОСНОВНАЯ ЧАСТЬ

Преобразование различных типов данных (изображений, голоса, текста) в числовые векторы имеет решающее значение для использования в моделях машинного обучения. Для каждого типа данных требуются специальные методы извлечения признаков, позволяющие зафиксировать его основные характеристики. При этом происходит преобразование изображения в вектор. Такое преобразование является необходимой операцией для обработки изображений с использованием обучения нейронных сетей. Поскольку нейронные сети могут обрабатывать только числовые данные, поэтому изображения необходимо представить в формате, который нейронная сеть может распознать и эффективно обработать.

Кроме того, преобразование изображений в цифровые векторы снижает сложность данных, облегчая нейронной сети обучение и выполнение классификации на основе входных данных изображения. Этот процесс также помогает сократить вычислительную нагрузку и время обучения. После введения в нейронную сеть цифровых векторов, информация проходит через все слои к выходному слою с использованием функции активации во всех встречающихся нейронах. Эта последовательность повторяется несколько раз и приводит к улучшению способности сети распознавать объекты.

В предлагаемой модели имеется три скрытых слоя. Первый скрытый слой содержит 512 нейронов, в состав второго скрытого слоя входят 256 нейронов, а третий скрытый слой имеет

128 нейронов. Все нейроны в этих слоях активируются по математической зависимости Relu. Эта функция используется для активации нейронов внутри слоев и имеет следующий вид:

$$f(x) = \max(0, x). \quad (1)$$

Выходной слой имеет содержит нейроны, на выходах которых формируются значения 0 или 1 с использованием функции Softmax, имеющей следующую математическую интерпретацию:

$$s(x) = \frac{e^{x_i}}{\sum_{j=1}^n e^{x_j}}. \quad (2)$$

где i – число выходов; j – число входов.

Сеть создавалась с помощью библиотеки *Keras*. Выбор этой библиотеки обусловлен её широким распространением. *Keras* является библиотекой глубокого обучения с открытым исходным кодом, которая написана на языке программирования *Python* и позволяет создавать прототипы нейронных сетей для исследовательских и производственных целей. Эта библиотека дает возможность создать нейронную сеть глубокого обучения для использования в целях прогнозирования и классификации [25]. Ключевые особенности *Keras* представлены в таблице 1.

В рамках проводимого исследования с использованием *Keras* важное значение имеет процесс преобразования изображений в оттенках серого в векторы. Он является одним из этапов подготовки графических данных для подачи на вход нейросети. Необходимость этого преобразования обусловлено тем, что данные, поступающие на вход нейросетевых слоев, должны быть представлены в виде одномерных массивов, т.е. векторов. В отличие от этого, входные графические данные МРТ-снимков не являются одномерными массивами. Изображение в оттенках серого представляет собой двумерный массив (или матрицу), где значение каждого пикселя соответствует интенсивности света в данной точке. Значения пикселей в 8-битном изображении обычно варьируются от 0 (черный) до 255 (белый). В качестве примера можно отметить, что изображение в оттенках серого размером 80×80 пикселей может быть представлено в виде двумерной матрицы соответствующего размера. Чтобы преобразовать МРТ-изображение в оттенках серого в вектор, необходимо преобразовать двумерный массив в одномерный. Для этого элементы исходной матрицы объединяются в единую непрерывную последовательность значений. Так, изображение размером 80×80 трансформируется в вектор длиной 6400 значений (результат произведения числа 80 на это же число). Результирующий вектор имеет следующий вид:

$$V = [I_{1,1}, I_{1,2}, \dots, I_{1,n}, I_{2,1}, I_{2,2}, \dots, I_{m,n}]. \quad (3)$$

где $I_{i,j}$ – значение в пикселях в строке номер i и столбце номер j .

Перед подачей полученного вектора на вход нейросети требуется выполнение нормализации, при которой значения пикселей масштабируются в диапазоне от 0 до 1. Это выполняется в целях улучшения сходимости искусственной нейронной сети в процессе обучения. Для 8-битных изображений нормализация, как правило, производится с помощью деления значения каждого пикселя на 255. Полученный нормализованный вектор подается на вход нейросети, в которой выполняется сопоставление данных вектора с меткой определенного класса.

Таблица 1

Ключевые особенности *Keras*

Table 1


Key Features of *Keras*

Характеристики	Детализация
Простота интерфейса	<ul style="list-style-type: none"> • доступный и высокопроизводительный интерфейс для решения задач машинного обучения; • согласованный интерфейс прикладного программирования, охватывающий каждый этап рабочего процесса машинного обучения от обработки данных до развертывания; • минимизирует когнитивную нагрузку благодаря понятным и лаконичным интерфейсам
Расширяемость и простота настройки параметров	<ul style="list-style-type: none"> • упрощенный функционал для создания нейронных слоев, функций потери данных и средств для решения задач предварительной обработки входных данных; • возможность создания сложных нейросетевых архитектур с использованием функционального интерфейса прикладного программирования или с использованием подклассов; • способность адаптации к различным исследовательским сценариям.
Способность функционирования на различных платформах	<ul style="list-style-type: none"> • совместимость со многими фреймворками глубокого обучения (TensorFlow, CNTK, Theano и др.); • возможность согласованного выполнения исследовательских задач на различных платформах, независимо от использования графического процессора; • возможность переноса нейросетевых моделей между различными серверными компонентами.
Сокращение времени исследования. Широкий функционал	<ul style="list-style-type: none"> • возможность создания программных прототипов и тестирования различных нейросетевых архитектур в течение ограниченного времени; • наличие многочисленных предварительно подготовленных нейросетевых моделей и библиотек; • поддержка многочисленных приложений, включая компьютерное зрение, прогнозирования временных рядов, обработку больших данных и др.

В целях сокращения времени нейросетевого обучения после загрузки набора входных данных были установлены размеры изображений 80×80 с использованием метода *resize* из программной библиотеки *OpenCV*. Указанная библиотека содержит программное обеспечение для компьютерного зрения и машинного обучения с открытым исходным кодом.

РЕЗУЛЬТАТЫ ИССЛЕДОВАНИЯ И ИХ ОБСУЖДЕНИЕ

Процесс обучения нейронной сети был повторен 55 раз. На рисунке 2 показаны кривые зависимости характеристик качества настройки нейросети от количества циклов обучения.



```
1 #Accuracy
2 val_loss , val_accu = model.evaluate(X,y)
```

7/7 [=====] - 1s 55ms/step - loss: 0.0206 - accuracy: 0.9955

Рис. 2. Характеристики качества настройки нейросети
Fig. 2. Characteristics of the quality of neural network tuning

Чтобы протестировать созданную нами нейронную сеть и оценить, насколько выходные значения близки к реальным, мы использовали ряд МРТ-изображений. Распознавание этих изображений с помощью созданной нейросетевой модели дает возможность их классифицировать. В таблице 2 представлены примеры результатов такой классификации, которые на выходе нейросети отображаются в виде одного из двух бинарных значений:

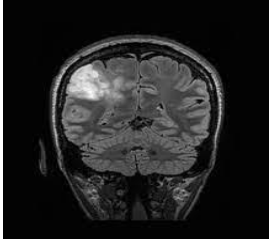
- 0 → означает, что это изображение здорового (не поврежденного) мозга.
- 1 → означает, что это изображение мозга с онкологическим заболеванием.

Результаты работы нейросетевой модели

Таблица 2

Results of the neural network model

Table 2

Изображение	Факт	Результат классификации
	Здоровый мозг	0 = Здоровый Мозг
	Поврежденный мозг	1 = Мозг с заболеванием

ЗАКЛЮЧЕНИЕ

Анализ характеристик распознавания 222 МРТ-изображений с использованием построенной FFNN-нейросети показал результаты, обладающие высокой точностью (более 99%). Предложенная в статье нейросетевая модель позволяет усовершенствовать процесс распознавания МРТ-изображений и повысить точность их классификации на 9,6 % по сравнению с традиционными методами. Благодаря своей способности обрабатывать большие объемы данных и изучать сложные взаимосвязи между признаками, FFNN являются эффективным инструментом для точной классификации серых изображений. Однако необходимы дальнейшие исследования для оптимизации работы предложенной модели и обеспечения надежных результатов в различных задачах классификации изображений.

Список литературы

1. Касаткин А.А., Лиманова Н.И., Козлов В.В. Разработка и применение алгоритмов машинного зрения и обработки изображений // Тенденции развития науки и образования. – 2023. – № 98-10. – С. 58–61.
2. Аверкин А.Н., Волков Е.Н., Ярушев С.А. Объяснительный искусственный интеллект в анализе цифровых изображений на основе нейронных сетей глубокого обучения // Известия Российской академии наук. Теория и системы управления. – 2024. – № 1. – С. 150–178.
3. Сухих Г.Т., Давыдов Д.Г., Логинов В.В. Состояние и перспективы внедрения технологий искусственного интеллекта в акушерско-гинекологическую практику // Акушерство и гинекология. – 2021. – № 2. – С. 5–12.
4. Наркевич А. Н. Т., Мамедов Х., Дзюба Д. В. Распознавание диабетической ретинопатии на цифровых изображениях глазного дна с применением сверточных нейронных сетей глубокого обучения // Технологии живых систем. – 2023. – Т. 20, № 1. – С. 55–61.
5. Дмитриева В.В., Тупицын Н.Н., Поляков Е.В., Денисюк С.С. Метод мультиклассификации клеток костного мозга для диагностики острых лейкозов и минимальной остаточной болезни (на материале лаборатории гемопоэза Национального медицинского исследовательского центра онкологии им. Н.Н. Блохина) // Системный анализ и управление в биомедицинских системах. – 2020. – Т. 19, № 3. – С. 155–158.
6. Елагина Е.А., Маргун А.А. Исследование методов машинного обучения в задаче идентификации клеток крови // Научно-технический вестник информационных технологий, механики и оптики. – 2021. – Т. 21, № 6. – С. 903–911.
7. Сафьянникова Е.А., Крюков А.И., Кунельская Н.Л. Возможности нейросети в диагностике новообразований гортани // Digital Diagnostics. – 2024. – Т. 5, № S1. – С. 98–101.
8. Шабалин В.В., Захарова Г.П., Кривопапов А.А. Выявление структурных маркеров хронического риносинусита на изображениях твердой фазы биологических жидкостей // Российская ринология. – 2023. – Т. 31, № 4. – С. 245–251.
9. Наркевич А. Н., Виноградов К. А., Параскевопуло К. М., Мамедов Т. Х. Интеллектуальные методы анализа данных в биомедицинских исследованиях: сверточные нейронные сети // Экология человека. – 2021. – № 5. – С. 53–64.
10. Velikanova A.S., Polshchikov K.A., Likhosherstov R.V., Polshchikova A.K. The use of virtual reality and fuzzy neural network tools to identify the focus on achieving project results // Journal of Physics: Conference Series. 2nd International Scientific Conference on Artificial Intelligence and Digital Technologies in Technical Systems 2021, Volgograd. – 2021. – Vol. 2060. – P. 173707.
11. Польщиков К. А., Лазарев С. А., Константинов И. С. Модель для оценки эффективности выполнения робототехнической системой коммуникативных функций // СТИН. – 2020. – № 6. – С. 4–7.
12. Rvachova N., Sokol G., Polschikov K., Davies J. N. Selecting the intersegment interval for TCP in telecomms networks using fuzzy inference system // 2015 Internet Technologies and Applications, ITA 2015 – Proceedings of the 6th International Conference. – Wrexham, 2015. – P. 256–260.
13. Konstantinov I.S., Polshchikov K.O., Lazarev S.A. The Algorithm for Neuro-Fuzzy Controlling the Intensity of Retransmission in a Mobile Ad-Hoc Network // International Journal of Applied Mathematics and Statistics. – 2017. – Vol. 56, Issue No. 2. – PP. 85–90.
14. Polshchikov K.O., Lazarev S.A., Zdorovtsov A.D. Neuro-Fuzzy Control of Data Sending in a Mobile Ad Hoc Network // Journal of Fundamental and Applied Sciences. – 2017. – Vol 9, No 2S. – PP. 1494–1501.

15. Махди Т.Н., Игитян Е.В., Польщиков К.А., Корсунов Н.И. Оценивание эффективности функционирования диалоговой системы на основе применения нечеткого вывода с нейросетевой настройкой // Экономика. Информатика. – 2022. – Т. 49. – № 2. – С. 356–374.
16. Polshchikov K.A., Velikanova A.S., Igityan E.V. Neural network natural language processing tools for identifying personal priorities in the project performers selection in the field of smart agriculture // IOP Conference Series: Earth and Environmental Science. – 2022. – Vol. 1069. – 012012.
17. Bhardwaj H., Tomar P., Sakalle A., Sharma U. Principles and Foundations of Artificial Intelligence and Internet of Things Technology // Artificial Intelligence to Solve Pervasive Internet of Things Issues. – 2021. – P. 377–392.
18. Grossi E., Buscema M. Introduction to artificial neural networks // European Journal of Gastroenterology & Hepatology. – 2007. – Vol. 19(12). – P. 1046–1054.
19. Capizzi G., Coco S., Lo Sciuto G., Napoli C. A new iterative fir filter design approach using a Gaussian approximation // IEEE Signal Processing Letters. – 2015. – Vol. 25. – P. 1615–1619.
20. Chen Y., Zhang C., Liu C. et al. Atrial Fibrillation Detection Using a Feedforward Neural Network // Journal of Medical and Biological Engineering. – 2022. – Vol. 42. – P. 63–73.
21. Sayal A. et al. Neural Networks and Machine Learning // 2023 IEEE 5th International Conference on Cybernetics, Cognition and Machine Learning Applications (ICCCMLA). – Hamburg, 2023. – P. 58–63.
22. Roy S., Bhalla K., Patel R. Mathematical analysis of histogram equalization techniques for medical image enhancement: a tutorial from the perspective of data loss // Multimedia Tools and Applications. – 2024. – Vol. 83. – P. 14363–14392.
23. Acharya U.K., Kumar S. Genetic algorithm based adaptive histogram equalization (GAAHE) technique for medical image enhancement // Optik. – 2021. – Vol. 230. – P. 166273.
24. Bachiega de Almeida T., Carlos Pedrino E., Merino Fernandes M. Complex Morphological Filtering for Serial, Parallel, GPU, SoC, PetaLinux and FPGA Execution // IEEE Latin America Transactions. – 2020. – Vol. 18(10). – P. 1675–1682.

References

1. Kasatkin A.A., Limanova N.I., Kozlov V.V. Development and application of machine vision and image processing algorithms // Trends in the Development of Science and Education. – 2023. – No. 98–10. – P. 58–61.
2. Averkin A.N., Volkov E.N., Yarushev S.A. Explanatory artificial intelligence in the analysis of digital images based on deep learning neural networks // Bulletin of the Russian Academy of Sciences. Theory and Control Systems. – 2024. – No. 1. – P. 150–178.
3. Sukhikh G.T., Davydov D.G., Loginov V.V. Status and prospects of introducing artificial intelligence technologies into obstetric and gynecological practice // Obstetrics and Gynecology. – 2021. – No. 2. – P. 5–12.
4. Narkevich A.N.T., Mamedov H., Dzyuba D.V. Recognition of diabetic retinopathy in digital fundus images using deep learning convolutional neural networks // Technologies of living systems. – 2023. – Vol. 20, No. 1. – P. 55–61.
5. Dmitrieva V.V., Tupitsyn N.N., Polyakov E.V., Denisyuk S.S. Method of multiclassification of bone marrow cells for the diagnosis of acute leukemia and minimal residual disease (based on the hematopoiesis laboratory of the N.N. Blokhin National Medical Research Center of Oncology) // Systems analysis and control in biomedical systems. – 2020. – Vol. 19, No. 3. – P. 155–158.
6. Elagina E.A., Margun A.A. Study of machine learning methods in the problem of blood cell identification // Scientific and Technical Bulletin of Information Technologies, Mechanics and Optics. – 2021. – Vol. 21, No. 6. – P. 903–911.
7. Safyannikova E.A., Kryukov A.I., Kunelskaya N.L. Capabilities of neural networks in diagnostics of laryngeal neoplasms // Digital Diagnostics. – 2024. – Vol. 5, No. S1. – P. 98–101.
8. Shabalin V.V., Zakharova G.P., Krivopalov A.A. Identification of structural markers of chronic rhinosinusitis in images of the solid phase of biological fluids // Russian Rhinology. – 2023. – Vol. 31, No. 4. – P. 245–251.
9. Narkevich A. N., Vinogradov K. A., Paraskevopulo K. M., Mamedov T. Kh. Intelligent methods of data analysis in biomedical research: convolutional neural networks // Human Ecology. 2021. – No. 5. – P. 53–64.
10. Velikanova A.S., Polshchikov K.A., Likhosherstov R.V., Polshchikova A.K. The use of virtual reality and fuzzy neural network tools to identify the focus on achieving project results // Journal of Physics: Conference Series. 2nd International Scientific Conference on Artificial Intelligence and Digital Technologies in Technical Systems 2021, Volgograd. – 2021. – Vol. 2060. – P. 173707.

11. Polshchikov K. A., Lazarev S. A., Konstantinov I. S. Model for assessing the effectiveness of a robotic system in performing communicative functions // STIN. – 2020. – No. 6. – P. 4–7.
12. Rvachova N., Sokol G., Polshchykov K., Davies J. N. Selecting the intersegment interval for TCP in telecomms networks using fuzzy inference system // 2015 Internet Technologies and Applications, ITA 2015 – Proceedings of the 6th International Conference. – Wrexham, 2015. – P. 256–260.
13. Konstantinov I.S., Polshchykov K.O., Lazarev S.A. The Algorithm for Neuro-Fuzzy Controlling the Intensity of Retransmission in a Mobile Ad-Hoc Network // International Journal of Applied Mathematics and Statistics. – 2017. – Vol. 56, Issue No. 2. – PP. 85–90.
14. Polshchykov K.O., Lazarev S.A., Zdorovtsov A.D. Neuro-Fuzzy Control of Data Sending in a Mobile Ad Hoc Network // Journal of Fundamental and Applied Sciences. – 2017. – Vol 9, No 2S. – PP. 1494–1501.
15. Mahdi T.N., Igityan E.V., Polshchikov K.A., Korsunov N.I. Evaluation of the dialogue system efficiency based on the application of fuzzy inference with neural network settings // Economics. Information technologies. – 2022. – Vol. 49. – No. 2. – P. 356–374.
16. Polshchykov K.A., Velikanova A.S., Igityan E.V. Neural network natural language processing tools for identifying personal priorities in the project performers selection in the field of smart agriculture // IOP Conference Series: Earth and Environmental Science. – 2022. – Vol. 1069. – 012012.
17. Bhardwaj H., Tomar P., Sakalle A., Sharma U. Principles and Foundations of Artificial Intelligence and Internet of Things Technology // Artificial Intelligence to Solve Pervasive Internet of Things Issues. – 2021. – P. 377–392.
18. Grossi E., Buscema M. Introduction to artificial neural networks // European Journal of Gastroenterology & Hepatology. – 2007. – Vol. 19(12). – P. 1046–1054.
19. Capizzi G., Coco S., Lo Sciuto G., Napoli C. A new iterative fir filter design approach using a Gaussian approximation // IEEE Signal Processing Letters. – 2015. – Vol. 25. – P. 1615–1619.
20. Chen Y., Zhang C., Liu C. et al. Atrial Fibrillation Detection Using a Feedforward Neural Network // Journal of Medical and Biological Engineering. – 2022. – Vol. 42. – P. 63–73.
21. Sayal A. et al. Neural Networks and Machine Learning // 2023 IEEE 5th International Conference on Cybernetics, Cognition and Machine Learning Applications (ICCCMLA). – Hamburg, 2023. – P. 58–63.
22. Roy S., Bhalla K., Patel R. Mathematical analysis of histogram equalization techniques for medical image enhancement: a tutorial from the perspective of data loss // Multimedia Tools and Applications. – 2024. – Vol. 83. – P. 14363–14392.
23. Acharya U.K., Kumar S. Genetic algorithm based adaptive histogram equalization (GAAHE) technique for medical image enhancement // Optik. – 2021. – Vol. 230. – P. 166273.
24. Bachiega de Almeida T., Carlos Pedrino E., Merino Fernandes M. Complex Morphological Filtering for Serial, Parallel, GPU, SoC, PetaLinux and FPGA Execution // IEEE Latin America Transactions. – 2020. – Vol. 18(10). – P. 1675–1682.

Ясир Муханад Джабар, кандидат технических наук, лектор, Южный технический университет, г. Басра, Ирак
Аль Жанзир Зуалфекар Муниф, аспирант, Институт инженерных и цифровых технологий, Белгородский государственный национальный исследовательский университет, г. Белгород, Россия

Yasser Muhanad Jabar, Candidate of Technical Sciences, Lecturer, Southern Technical University, Basra, Iraq
Al Janzeer Zualfekar Munif, Postgraduate student, Institute of Engineering and Digital Technologies, Belgorod State National Research University, Belgorod, Russia